

차세대 공중전술네트워크를 위한 Learning-Backoff 기반 무선 채널 접속 방법

변정훈¹, 박상준², 윤준혁², 김용철², 이원우², 조오현^{3*}, 주태환⁴

¹충북대학교 소프트웨어학과 학생, ²육군사관학교 전자공학과 교수, ³충북대학교 소프트웨어학과 교수, ⁴국방과학연구소

Learning-Backoff based Wireless Channel Access for Tactical Airborne Networks

JungHun Byun¹, Sangjun Park², Joonhyeok Yoon², Yongchul Kim²,
Wonwoo Lee², Ohyun Jo^{3*}, Taehwan Joo⁴

¹Student, Department of Computer Science, Chungbuk National University

²Professor, Department of Electrical Engineering, Korea Military Academy

³Professor, Department of Computer Science, Chungbuk National University

⁴Agency for Defense Development(ADD)

요약 원활한 작전 수행을 통한 국방력의 강화를 위해 전술네트워크의 기능은 필수적이다. 전시 상황에서 다양한 전술, 전략은 수많은 정보들을 근거로 한다. 이를 위해 정찰기를 비롯한 다양한 정보 수집 장치 및 자원들이 방대한 양의 정보 수집을 위해 사용되고, 이들 대다수는 전술네트워크를 통해 정보를 전달한다. 채널의 사용 여부를 판단하여 상황에 따라 경쟁 기반으로 채널에 접속을 하는 국방전술네트워크 환경에서, 매우 높은 이동성을 갖는 정찰기 등 고속 이동 노드는 불필요한 채널 점유로 인하여 잠재적인 성능 열화 문제가 발생할 수 있다. 본 논문에서는 채널 예약 시점을 정하는 경쟁 윈도우(Contention Window)의 크기를 경험적으로 학습시켜 네트워크 처리량을 증가시키는 Learning-Backoff 방식의 무선 채널 접속 방법을 제안한다. 제안하는 방법은 고속 이동 노드의 수가 많아짐에 따라 더욱 좋은 성능을 보이고 있으며, 정찰기 4대가 운영되는 특정 작전 시나리오에 적용하였을 경우 처리량이 최대 25% 증가한다.

주제어 : 강화학습, Q-러닝, 공중 전술 네트워크, Learning-Backoff 통신, CSMA/CA

Abstract For strengthening the national defense, the function of tactical network is essential. tactics and strategies in wartime situations are based on numerous information. Therefore, various reconnaissance devices and resources are used to collect a huge amount of information, and they transmit the information through tactical networks. In tactical networks that which use contention based channel access scheme, high-speed nodes such as recon aircraft may have performance degradation problems due to unnecessary channel occupation. In this paper, we propose a learning-backoff method, which empirically learns the size of the contention window to determine channel access time. The proposed method shows that the network throughput can be increased up to 25% as the number of high-speed mobility nodes are increases.

Key Words : Reinforcement learning, Q-learning, Tactical Airborne Networks, Learning-Backoff Communication, CSMA/CA

*This work was supported by Agency for Defense Development(ADD) under Grant(UD190011ED)

*Corresponding Author : Ohyun Jo (ohyunjo@chungbuk.ac.kr)

Received December 9, 2020

Revised January 6, 2021

Accepted January 20, 2021

Published January 28, 2021

1. 서론

전시에서는 원활한 전술 운용과 효율적인 작전 수행을 위해서 수많은 정보가 수집되어야 한다. 적들보다 많고, 빠른 정보 수집은 더욱 유연한 전술 운용을 가능하게 함으로써 우리 군의 전투력 향상에 이바지할 수 있다. 대량의 정보를 효율적으로 수집하기 위해서는 정보 수집 장치가 높은 이동성을 갖고, 지리적으로 분산되어져 있어야 한다. 이를 위한 공중전술네트워크는 높은 이동성을 지원하면서도 음영지역을 최소화하여야 한다.

국방전술네트워크와 같이 분산 환경에서 여러 노드들이 경쟁기반으로 접속하는 무선 네트워크에서는 높은 이동성을 갖는 노드가 네트워크의 성능을 저하시킬 가능성이 존재한다. 반이중 통신을 사용하는 무선 네트워크에서는 충돌의 감지가 거의 불가능하기 때문에 여러 노드들이 같은 채널을 사용하면 CSMA/CA(Carrier Sense Multiple Access with Collision Avoidance)[1]라는 충돌 회피 다원 접속 매체 접근 방식을 사용하는데, 이 방식은 RTS/CTS 프레임을 사용하여 채널 예약 여부를 주변 노드에게 알리고 충돌을 회피함으로써 한 채널에서 다수의 노드들이 효율적으로 채널을 공유할 수 있게 만든다. 하지만 국방전술네트워크의 정찰기와 같이 매우 높은 이동성을 갖는 노드가 존재하는 경우, 높은 이동성에 의한 네트워크 토폴로지 변화로 인하여 RTS/CTS에 의한 채널 예약 정보가 유효하지 않게 되는 상황이 빈번하게 발생한다.

따라서 본 논문에서는 네트워크 처리량의 손실을 만회하기 위한 방법으로, Q-러닝[2]을 사용한 경쟁 윈도우(Contention Window)의 Backoff 시간 학습(Learning-Backoff)을 통해 전체 네트워크 처리량을 증가시키는 방법을 제안한다. Q-러닝은 적은 자원으로 변화하는 환경에 시스템이 적응 가능하게 만드는 강화 학습 기법[3]으로, 네트워크 분야에서도 많은 연구가 진행되고 있다[4-9].

본 논문은 다음과 같이 구성되어 있다. 2장에서는 차세대 공중전술네트워크의 개념과 이에 기반을 둔 작전 시나리오를 소개한다. 3장에서는 제안하는 Learning-Backoff 알고리즘과 시뮬레이션 환경을 설명한다. 다음으로, 4장에서 기존의 Random Backoff 방식과 제안하는 Learning-Backoff 방식의 성능을 비교하고, 마지막으로 5장에서 결론을 제시한다.

2. 차세대 공중 전술 네트워크

2.1 공중 전술 네트워크 국내외 동향

공중기반 네트워크의 운용은 다양한 분야에서 활발하게 연구가 진행되고 있다. 민간에서는 드론이나 무인기를 컨트롤하기 위한 수단으로 공중네트워크에 대한 연구가 진행되어 왔으며[10], 최근에는 상용망에서 요구되는 대용량 데이터를 효율적으로 전송하기 위한 수단중 하나로 연구되고 있다[11]. 성층권을 비행하는 고고도 열기구들을 상공 20km고도에 배치하여 지상 단말기와 열기구 간 통신을 제공하였으며, 태양전지판을 이용하여 100일 이상 운용이 가능하였다.[12] 최근에는 특정위치에서 UAV(Unmanned Aerial Vehicle)를 고정적으로 활용하여 통신을 중계하는 개념이 제안된 바있으며, 중계기의 위치 제어가 자유로워 기상상태 및 장애물 등에 의한 신호감쇄를 효과적으로 해결하였다.[13]

군에서는 네트워크 중심의 전쟁개념이 발달하면서 2000년대 초반부터 모든 시스템을 연결하여 작전을 수행하는 GIG(Global Information Grid) 개념[14]이 미국 국방부에 의해 언급되기 시작하였다. 이에 따라 모든 계층의 장비들을 네트워크로 연결하기 위한 Joint Airborne Network (JAN)[15] 개념이 연구되기 시작하면서 Fig. 1에서 보이는 것처럼 군사작전에 있어 공중에 있는 장비들을 네트워크로 사용하기 위한 공중네트워크의 개념연구가 본격적으로 시작되었다.

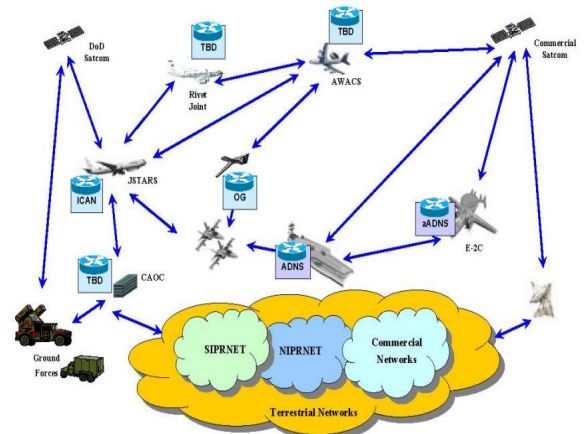


Fig. 1. Joint Airborne Network Vision

2.2 다중빔 기반 다계층 공중전송네트워크

감시정찰용 초소형군집드론 및 무인기, 유·무형 복합 전투헬기, 공중지휘소 및 관제소들은 미래의 전장에서 활발하게 운용될 수 있다. 이에 따라, 공중에서 다중빔 안테나를 활용한 공중전송네트워크의 필요성이 증대되었으며, 특히 공중에서뿐만 아니라 모든 계층에서의 네트워크를 보장하기 위한 다중빔 기반의 다계층 공중전송네트워크의 필요성은 증대되었다.

감시정찰용 군집드론 및 무인기 등 공중에서 운용되는 장비들의 성능이 개선됨에 따라서 작전범위가 확대되고 있고 이러한 경향은 미래에도 지속될 것으로 예상된다. 따라서 넓은 범위에서의 작전을 보장해야 한다는 특성이 있다.

공격작전의 성공이후 신속하게 전과확대를 하거나 기타 작전 중 특정 노드통신소가 파괴되는 경우 예상치 못한 지역과 장비에 추가노드통신소의 운용이 필요하며, 다양한 계층에서 운용될 수 있기 때문에 상하위 계층의 체계들을 연결하기 위한 공중노드 네트워크가 구성되어야 한다.

그렇기 때문에 다중빔 기반의 다계층공중전송 네트워크를 운용하기 위해서는 On-Demand 통신지원이 가능해야하며, 광역 및 대용량 통신을 지원해야 한다. 또한, 동적 라우팅 기능과 신속하고 정확한 빔포밍 기능을 지원해야 한다. 그리고 다계층 핸드오버, 운용환경에 링크를 최적화해야하며, 최적의 RAT 및 네트워크 선택 기능에 대한 지원이 고려되어야 한다.

2.3 공중전송네트워크 기반 작전 시나리오



Fig. 2. Multi-beam Antenna Operation Scenario

Fig. 2.에서 감시정찰 무인기의 운용 방법 중 무인기

4대의 정보유통을 지원하기 위해 공중노드통신소 1대를 운용하고 지상의 지휘소와 통신링크를 지원하는 공중노드 통신소 1대를 별도로 운용하는 개념을 보여주고 있다. 한 대의 감시정찰 무인기는 제대에 따라 그 운용거리가 수백 km에 이른다. 한편, 각각의 무인기들은 고정된 위치에서 운용되는 것이 아니라 특정지역을 선회하고 4대의 무인기는 서로 다른 지역에서 독립적으로 운용된다.

또한, 자체회랑운용과 통신거리를 고려하여 운용할 경우, 여러 대의 노드통신소가 공중전송네트워크를 구성하여 적 후방 깊은 지역에서 운용되는 감시정찰 무인기의 정보유통지원이 가능해진다. 감시정찰 무인기와 공중노드 통신소 모두 회랑을 이동하기 때문에 다중빔을 형성하고 빔 지향 방향이 동적으로 전환하는 기술이 적용되어야 한다.

3. Learning-Backoff 기반 무선 접속

3.1 기존 문제점

무선공중전송네트워크에서 무인정찰기와 고속 이동노드는 높은 이동성으로 인한 네트워크 토폴로지 변화에 따른 채널 예약의 유효성 문제로 인하여 채널 사용 효율을 열화시키는 문제점이 있다. 높은 이동성을 갖는 노드일수록 다음과 같은 상황을 발생시킬 수 있다.

- 1) RTS 또는 CTS를 듣지 못하고 채널에 진입
- 2) RTS 전송 후 CTS를 듣지 못하고 채널을 벗어남
- 3) RTS와 CTS를 주고받았으나 채널을 벗어남

정찰기의 상황이 1번 같은 경우에는 채널을 예약한 다른 노드와 충돌이 나게 됨으로써 데이터 전송 실패와 재전송을 유도하게 된다. 2, 3번의 경우는 정찰기와 수신측 노드 사이에 데이터 전송이 이루어지지 않고 있지만, 수신측 노드 주변의 모든 노드들은 데이터를 보내도 문제가 없어도 채널을 사용할 수 없는 상황에 놓이게 된다. 이러한 원인으로 인한 네트워크 성능 열화의 정도는 수신 노드의 통신 범위를 넘나드는 이동성 노드의 수가 많아질수록 증가한다.

3.2 Learning Backoff 기반 무선 채널 접속

제안하는 Learning Backoff 방법은 경쟁 윈도우 크

기 안에서 랜덤하게 Backoff를 선택하는 기존의 Random-Backoff 방식과 다르게 Backoff를 선택 후 통신 성공여부에 따라 보상을 주어 학습 시키는 방법을 사용한다. 정찰기는 최초로 통신을 시도할 때 Backoff 값을 임의로 선택하며, 통신 성공여부에 따라 Q-테이블의 보상값을 저장하는 공간에 보상을 준다. 제안하는 Learning Backoff 방법은 E-Greedy를 사용하기 때문에 처음에는 랜덤하게 Backoff를 선택하지만, 학습이 진행됨에 따라 점차 Q-테이블의 보상값이 가장 높은 Backoff를 선택하게 된다.

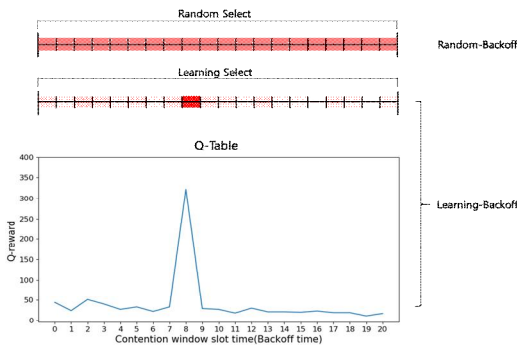


Fig. 3. Compensation value of Q-table

```

Learning-Backoff Algorithm :
exploration = 1 - (timer / simulation_time)
if random(1) < exploration:
    Backoff_counter = random_int(0, max_window_size)
else:
    Backoff_counter = max_index(Q_table)

if communication_success():
    Q_table[Backoff_counter] += reward
    
```

Fig. 4. Learning-Backoff Algorithm

Fig. 3은 Learning-Backoff의 학습이 끝난 후 Q-테이블에 저장된 보상값과 Random-Backoff 방식과 Learning-Backoff 방식의 Backoff 선택 비율을 보여 준다. 아래의 그래프는 Q-테이블에 누적된 보상값을 보여주며, 위에서는 보상값의 비율을 시각적으로 보기 편하게 색으로 나타낸다. Random-Backoff 방식은 경쟁 윈도우 안에서 선택된 Backoff의 횟수가 고르게 분포되어 있지만, Learning-Backoff 방식은 Fig. 4의 E-Greedy 알고리즘 절차를 따라서 학습이 진행됨에 따라 적절한 Backoff값을 찾아낸다. 1에서 0까지 줄어

드는 Exploration 변수에 의해 Backoff값을 랜덤하게 선택하는 방법과 Q-테이블에서 가장 큰 보상값을 갖는 Backoff값을 선택하는 방법이 결정되고, 결정된 Backoff 값을 사용했을 때의 통신 성공 여부에 의해서 Q-테이블에 Reward가 주어진다. 통신이 성공했을 경우 Q-테이블 인덱스에 Reward로 1이 주어지며, 통신이 실패했을 때에는 Reward가 주어지지 않는다. Q-테이블은 Backoff가 통신이 성공했을 경우에만 해당 인덱스에 보상이 쌓이는 구조이기 때문에 큰 보상값을 갖는 인덱스는 시뮬레이션 환경에서 많은 통신을 성공시켰다는 것을 의미한다. 제안하는 방법은 이렇게 쌓인 Q-테이블의 값을 통해 정찰기에서 사용할 최적의 Backoff를 찾아낸다.




Fig. 5. Learning-Backoff and Integrated Learning methods

또한, 제안하는 Learning-Backoff 방식은 Fig.5과 같이 정찰기마다 독립된 Q-테이블을 사용하는 기본 Learning-Backoff 방식과 모든 정찰기가 동일한 Q-테이블을 사용하는 Integrated Learning-Backoff 방식 두 가지로 나뉜다.

Learning-Backoff 방식은 각 정찰기가 독립된 Q-테이블을 사용함으로써 서로 다른 Backoff를 선택하게 되지만, 학습을 통해 뒤늦게 들어온 정찰기의 Backoff가 앞서 이미 채널을 사용하고 있는 정찰기의 통신을 방해하지 않게끔 선택된다는 장점을 갖는다.

반면에 Integrated Learning-Backoff 방식은 두 정찰기가 Q-테이블을 공유함으로써 늦게 네트워크에 진입한 정찰기가 있는 경우 기존의 채널을 사용하고 있는 정찰기의 통신에 초기에 영향을 미칠 수 있지만, 두 정찰기가 통신 범위 안에 있을 때는 충돌확률을 감소시킬 수 있는 장점이 있다. 따라서 공정한 채널 사용을 보장하면서 충돌 확률을 줄임으로써 네트워크 처리량에 추가적인 성능 향상을 얻을 수 있다.

4. Learning-Backoff 성능 분석

4.1 정찰 시나리오의 시뮬레이션 환경

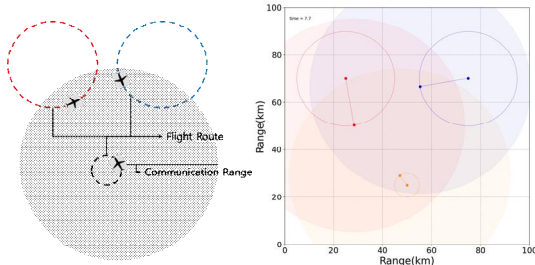


Fig. 6. Recon flight simulation

Table 1. Simulation environment

Simulator	Python	
Radius of flight route	Recon aircraft	20 km
	Receiving aircraft	5 km
Communication Range	40 km	
Position	Recon aircraft	(25, 70) (75, 70)
	Receiving aircraft	(50, 25)
Flight speed	250 km/h	
Flight direction	Clockwise	
RTS, CTS, SIFS, ACK, Slot time	10 μ s	
DIFS	50 μ s	
Data Frame	200 μ s	

제안 알고리즘의 시스템 레벨 성능 분석을 위해 파이썬의 Matplotlib 라이브러리를 사용하였다. 시뮬레이션의 시나리오는 Fig. 6과 같이 배치 되어있고, 시뮬레이션 환경의 정의를 위한 파라미터들은 Table 1과 같이 설정되었다. 정찰 시나리오에는 250km/h의 속도로 시계방향 등속운동을 하는 수신 공중 노드 1대와 정찰기가 최대 4대까지 배치된다. 수신 공중 노드는 내륙의 상공에서 반지름 5km를 갖는 경로를 따라 비행하며 정찰기로부터 지속적으로 데이터를 수신한다. 정찰기는 반지름 20km를 갖는 경로로 정찰 지역을 움직이며 데이터를 수집한다. 수신 공중 노드의 통신 범위의 한계는 40km로, 정찰기는 수신 공중 노드의 통신 범위에 들어가면 데이터 전송을 시도한다. RTS, CTS, SIFS, ACK, 경쟁 윈도우의 Slot time은 각각 10 μ s, DIFS는 50 μ s, Data Frame은 100 μ s의 길이로 설정되었다.

4.2 공중전송네트워크 처리량 변화




Fig. 7. Variation of network throughput

제안하는 방법을 적용한 후 네트워크에 미치는 성능을 평가하기 위한 지표로서 네트워크 Throughput을 측정하였다. 네트워크의 Throughput은 수신비행기의 통신 범위 안에 존재하는 시간과 실제 데이터가 전송된 시간으로 구해지며, 식은 다음과 같다.

$$\text{Throughput} = \frac{\text{Data transfer time}}{\text{Time on network}} \quad (1)$$

기존 Random-Backoff 방식과 Learning-Backoff 방식의 시뮬레이션 진행에 따른 처리율 변화는 Fig. 7에 나타난다. 정찰기가 수신 공중 노드의 통신 범위에 들어가기 전까지 0이었던 처리율은 첫 비행기가 진입하는 15,000 μ s부터 처리율이 계산된다. 약 42ms까지는 두 방식의 처리율에 큰 차이가 보이지 않지만, 이동성으로 인한 토폴로지 변화가 네트워크에 영향을 주기 시작하는 시점부터 Throughput의 차이가 나타나기 시작한다. Random-Backoff 방식은 처리율이 시간이 흘러도 변화가 없는 반면 Learning-Backoff 방식은 학습이 진행됨에 따라 정찰기 사이의 충돌이 줄고 점차 처리율이 증가하는 것을 확인 할 수 있다. Fig. 7의 결과를 통해 Q-러닝 학습을 적용한 Learning-Backoff 알고리즘이 기존 Random-Backoff 방식보다 Throughput 향상에 도움이 된다는 사실을 알 수 있다.

4.3 시나리오 변화에 따른 처리량

앞선 Fig. 5의 결과는 정찰기가 2대만 네트워크에 진입하는 상황을 고려했지만, 실제 상황에서는 더욱 많은 정찰기의 운용이 동시에 네트워크에서 이루어 질 수 있다. 이러한 정찰기 변화에 따른 네트워크의 성능 측

정을 위한 시뮬레이션 결과는 Fig. 8과 같다.

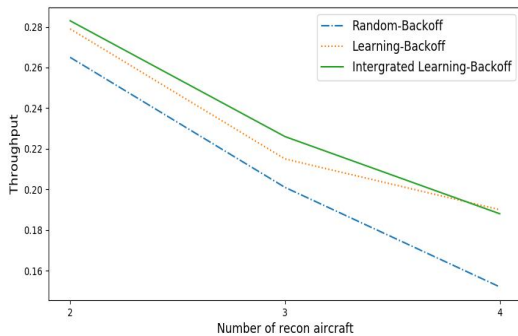


Fig. 8. Network Throughput according to the number of recon aircrafts

Fig. 8의 결과는 Q-러닝을 사용해 Backoff를 학습시킨 방식이 네트워크의 고속 이동 노드의 수가 많아질 수록 기존의 Random-Backoff 보다 우수한 네트워크 처리율을 보인다. 정찰기가 2대일 때에 Learning-Backoff와 Integrated Learning-Backoff 방식은 각각 5.3%, 6.8%의 처리율이 증가했고, 3대일 때 7%, 12.4%, 4대일 때 25%, 23.7%의 처리율 향상을 보여준다. 정찰기의 수가 증가함에 따라 Learning-Backoff 방식은 Backoff 선택이 학습되어 정찰기의 통신이 스케줄링 되는 효과가 생기기 때문에 상대적으로 처리율이 덜 감소한다. 이러한 실험 결과는 다수의 정찰기가 네트워크 안에 존재할 때 제안하는 방법이 Random하게 Backoff를 선택하는 것 보다 전체 네트워크 처리량 향상에 도움이 될 수 있음을 보여준다. 따라서 Backoff가 고정되어짐에 따라 자동적인 스케줄링 효과가 다수의 노드를 갖는 네트워크에서 처리율 유지에 더 효율적임을 알 수 있다.

5. 결론

본 논문에서는 경쟁 기반의 무선 채널 접속을 하는 공중전술네트워크 환경에서, 고속 이동을 하는 노드에 대한 Backoff 선택 학습이 네트워크 처리량에 미치는 영향을 시뮬레이션을 통해 확인하였다. Q-테이블의 공유 여부에 따라 Learning-Backoff와 Integrated Learning-Backoff로 나뉘는 두 방식은 모두 기존 Random-Backoff 방식보다 네트워크 처리량이 증가했으며, 고속 이동하는 노드의 수에 따라 각각 25%,

23.7% 높은 네트워크 처리율을 보여준다. 또한 기본적인 Q-러닝의 E-Greedy 알고리즘을 사용한 결과인 만큼, Learning 알고리즘에 따라 추가적인 성능 개선의 가능성이 있다.

REFERENCES


- [1] G. Bianchi, L. Fratta & M. Oliveri. (1996, October). Performance evaluation and enhancement of the CSMA/CA MAC protocol for 802.11 wireless LANs. *In Proceedings of PIMRC'96-7th International Symposium on Personal, Indoor, and Mobile Communications* (Vol. 2, pp. 392-396). IEEE.
DOI : 10.1109/PIMRC.1996.567423
- [2] C. J. Watkins & P. Dayan. (1992). Q-learning. *Machine learning*, 8(3-4), 279-292.
- [3] R. S. Sutton & A. G. Barto. (2018). *Reinforcement learning: An introduction*. MIT press.
- [4] S. H. Park & O. Jo. (2020). Q-NAV: NAV Setting Method based on Reinforcement Learning in Underwater Wireless Networks. *arXiv preprint arXiv:2005.13521*.
- [5] S. H. Park, K. Shin & O. Jo. (2020). AQ-NAV: Reinforced Learning Based Channel Access Method Using Distance Estimation in Underwater Communication. *Journal of Convergence for Information Technology*, 10(7), 33-40.
DOI : 10.22156/CS4SMB.2020.10.07.033
- [6] S. Galzarano, A. Liotta & G. Fortino. (2013, December). QL-MAC: A Q-learning based MAC for wireless sensor networks. *In International Conference on Algorithms and Architectures for Parallel Processing* (pp. 267-275). Springer, Cham.
- [7] N. Aihara, K. Adachi, O. Takyu, M. Ohta & T. Fujii. (2019). Q-learning aided resource allocation and environment recognition in LoRaWAN with CSMA/CA. *IEEE Access*, 7, 152126-152137.
DOI : 10.1109/ACCESS.2019.2948111
- [8] S. Bao & T. Fujii. (2011, November). Q-learning based p-persistent csma mac protocol for secondary user of cognitive radio networks. *In 2011 Third International Conference on Intelligent Networking and Collaborative Systems* (pp. 336-337). IEEE.
DOI : 10.1109/INCoS.2011.140
- [9] S. Cho. (2020). Rate adaptation with Q-learning

in CSMA/CA wireless networks. *Journal of Information Processing Systems*, 16(5), 1048-1063.
DOI : 10.3745/JIPS.03.0148

- [10] S. Hayat, E. Yanmaz & R. Muzaffar. (2016). Survey on unmanned aerial vehicle networks for civil applications: A communications viewpoint. *IEEE Communications Surveys & Tutorials*, 18(4), 2624-2661.
DOI : 10.1109/COMST.2016.2560343
- [11] C. I. Yeo, Y. S. Heo, J. H. Ryu, S. W. Park, S. C. Kim, H. S. Kang & G. H. Lee. (2020). Recent R&D Trends in Wireless Network Technology based on UAV-assisted FSO Technique. *[ETRI] Electronics and Telecommunications Trends*, 35(2), 38-49.
- [12] W. Fawaz, C. Abou-Rjeily & C. Assi. (2018). UAV-aided cooperation for FSO communication systems. *IEEE Communications Magazine*, 56(1), 70-75.
DOI : 10.1109/MCOM.2017.1700320
- [13] B. Moision et al. (2017, February). Demonstration of free-space optical communication for long-range data links between balloons on Project Loon. *In Free-Space Laser Communication and Atmospheric Propagation XXIX* (Vol. 10096, p. 100960Z). International Society for Optics and Photonics.
- [14] P. Wolfowitz. (2002). Global Information Grid (GIG) Overarching Policy. *US Department of Defense, directive*, (8100.1).
- [15] R. Trafton & S. V. Pizzi. (2006, October). The joint airborne network services suite. *In MILCOM 2006-2006 IEEE Military Communications conference* (pp. 1-5). IEEE.
DOI : 10.1109/MILCOM.2006.302496

변 정 훈(Junghun Byun)


[학생회원]



- 2019년 2월 : 한국교통대학교 컴퓨터공학과(학사)
- 2019년 3월 ~ 현재 : 충북대학교 컴퓨터과학 석사과정
- 관심분야 : 머신러닝, 전술네트워크, 수중 무선네트워크
- E-Mail : JHByun@chungbuk.ac.kr

박 상 준(Sangjun Park)


[정회원]



- 2000년 2월 : 육군사관학교 전자공학과 (학사)
- 2010년 2월 : 한국과학기술원 정보통신공학(석사)
- 2016년 7월 ~ 현재 : 육군사관학교 전자공학과 교수
- 관심분야 : 전자기파 해석, 마이크로웨이브 회로설계, 안테나 및 레이더
- E-Mail : sigpsj13438@kma.ac.kr

윤 준 혁(Joonhyeok Yoon)

[정회원]



- 2012년 2월 : 육군사관학교 전자공학(학사)
- 2018년 8월 : Purdue University 전자컴퓨터공학(석사)
- 2019년 3월 ~ 현재 : 육군사관학교 전자공학과 강사
- 관심분야 : 컴퓨터비전, 딥러닝, SLAM
- E-Mail : yjh9001@kma.ac.kr

이 원 우(Wonwoo Lee)

[정회원]



- 1989년 2월 : 육군사관학교 전자공학(학사)
- 1993년 2월 : 서강대학교 전자공학(석사)
- 2001년 8월 : Sytacuse University 전자공학(박사)
- 1993년 3월 ~ 현재 : 육군사관학교 전자공학교수
- 관심분야 : 전자기파 해석, 마이크로웨이브 회로설계, 안테나 및 레이더
- E-Mail : wlee01@kma.ac.kr


김 용 철(Yongchul Kim) [정회원]



- 1998년 2월 : 육군사관학교 전자공학(학사)
- 2001년 11월 : University of Surrey 전자공학과 (석사)
- 2012년 1월 : North Carolina State University 전자공학과 (박사)

- 2012년 6월 ~ 현재 : 육군사관학교 전자공학과 교수
- 관심분야 : 전자기파 해석, 마이크로웨이브 회로설계, 안테나 및 레이더
- E-Mail : kyc6454@kma.ac.kr

조 오 현(Ohyun Jo) [정회원]



- 2005년 2월 : 한국과학기술원 전기 및전자공학(학사)
- 2007년 8월 : 한국과학기술원 전기 및전자공학(석사)
- 2011년 2월 : 한국과학기술원 전기 및전자공학(박사)

- 2011년 4월 ~ 2016년 2월 : 삼성전자 DMC 연구소
- 2016년 3월 ~ 2017년 7월 : 한국전자통신연구원
- 2017년 8월 ~ 2018년 2월 : 육군사관학교 조교수
- 2018년 3월 ~ 2020년 9월 : 충북대학교 조교수
- 2020년 10월 ~ 현재 : 충북대학교 부교수
- 관심분야 : IoT 융합, 정보통신 및 네트워크, 기계학습
- E-Mail : ohyunjo@chungbuk.ac.kr

주 태 환 (Taehwan Joo) [정회원]



- 2008년 2월: 부산대학교 전기 및 전자공학부 (학사)
- 2010년 2월: KAIST 전기전자공학과 (석사)
- 2014년 2월: KAIST 전기전자공학과 (박사)

- 2016년 10월 ~ 현재: 국방과학연구소 선임연구원
- 관심분야 : RF Transceiver, 데이터링크 시스템
- E-Mail : jooth@add.re.kr